

变转速工况下松动故障自适应时频模态分解¹

单振¹⁾²⁾, 汤佳琛³⁾, 王重秋¹⁾, 杨建华^{2)✉}, 郝晨航²⁾, 李尚袁²⁾

1) 中国矿业大学计算机科学与技术学院, 徐州 221116 2) 中国矿业大学机电工程学院, 徐州 221116 3) 徐州重型机械有限公司, 徐州 221004

✉ 通信作者, E-mail: jianhuayang@cumt.edu.cn

摘要 松动故障广泛存在于机械设备之中, 而在变转速工况下的松动故障诊断仍存在一定挑战。为实现变转速工况下的松动故障诊断, 本文提出了一种自适应时频模态分解方法。为提高该方法的多工况自适应能力, 针对时频模态分解窗宽参数进行了优化选取, 研究了窗宽参数与分解输出的非线性关联特征, 实现了不同噪声下的自适应时频模态分解。为验证该方法的有效性, 针对支承松动故障进行了实验验证, 同时在某工程设备上进行了旋转部件松动故障实验验证。采用自适应时频模态分解算法对实验验证数据进行处理, 实现了非平稳特征的模态分解。通过定义和计算各阶次能量占比, 完成了振动信号的故障特征分析, 实现了松动故障的特征提取与诊断。结果表明, 所提方法能够实现非平稳信号的模态分解, 对于松动故障具备有效的诊断能力。

关键词 变转速工况; 模态分解; 松动故障; 强噪声

分类号 TH133.3

Bearing looseness fault diagnosis based on adaptive time-frequency modal decomposition under variable operating conditions

SHAN Zhen¹⁾²⁾, TANG Jia-chen³⁾, WANG Zhong-qiu¹⁾, YANG Jian-hua^{2) ✉}, HAO Chen-hang²⁾, LI Shang-yuan²⁾

1) School of Computer Science and Technology, China University of Mining and Technology, Xuzhou 221116, China

2) School of Mechanical and Electrical Engineering, China University of Mining and Technology, Xuzhou 221116, China

3) Xuzhou Heavy Machinery Co., Ltd., Xuzhou 221004, China

✉ Corresponding author, E-mail: jianhuayang@cumt.edu.cn

ABSTRACT Looseness faults are widely present in mechanical equipment, and the diagnosis of looseness faults under variable speed conditions still poses certain challenges. To achieve looseness fault diagnosis under variable speed operating conditions and tackle this challenge, a time-frequency modal decomposition method is proposed in this paper. To enhance the adaptability of this method for different operating conditions, the parameter window width is optimized and selected, thus obtaining adaptive time-frequency modal decomposition. Experimental validations are conducted on both bearing seat looseness faults and rotating component looseness faults. In the bearing seat looseness fault experiment, a comprehensive analysis of time-domain waveforms, time-frequency plots, and the output of adaptive time-frequency modal decomposition successfully achieves accurate diagnosis of the looseness fault. In the rotating component looseness fault experiment, effective diagnosis of the rotating component looseness fault is achieved through the processing of variable

收稿日期:

基金项目: 国家自然科学基金资助项目(12072362)

地址: 北京市海淀区学院路 30 号

E-mail: xuebaozr@ustb.edu.cn

邮政编码: 100083

<http://cje.ustb.edu.cn>

电话: 010-62333436

speed bearing vibration signals. Based on the proposed method, the fault features in the experimental signals were effectively extracted. In the experiment on bearing seat looseness faults, a comprehensive analysis of time-domain waveforms, time-frequency plots, and the output of adaptive time-frequency modal decomposition allowed us to successfully capture the characteristic information related to the looseness fault. Experimental results verified the effectiveness of the method, looseness faults caused by bearing seat looseness, and rotating parts looseness faults were both diagnosed by the proposed adaptive time-frequency modal decomposition algorithm. The experimental results show that the proposed method can achieve modal decomposition of non-stationary signals and has effective diagnostic capabilities for looseness faults. Overall, this research demonstrates the effectiveness of the adaptive time-frequency modal decomposition method in diagnosing looseness faults under variable speeds and strong noise backgrounds. The method is not only applicable to different types of looseness faults but also exhibits adaptability by optimizing parameters under varying noise intensities. It should be pointed out that during the use of this method, it needs to be based on the instantaneous speed information of the device, which may to some extent limit the applicability of this method. However, in practical engineering, the technical difficulty of speed measurement is relatively low, and many existing large-scale equipment is equipped with speed measurement devices, providing a hardware foundation for the application of this method. It can be seen that the above technical limitations can be easily resolved. The theoretical analysis and experimental verification of this article indicate that this innovative approach expands the application potential in the field of signal decomposition, providing a powerful tool for the health monitoring of mechanical equipment.

KEY WORDS Variable speed; modal decomposition; looseness fault; noise

旋转机械是工业生产的核心装备之一，其安全稳定运行对于工业生产具有重要意义。在实际运行环境中，机械设备常常工作在高温高压高振动的恶劣工况中。旋转设备一旦发生故障，对于人身和财产安全带来极大威胁。因此，对旋转机械进行状态监测与故障诊断具有重要意义^[1]。

在工程实际中，松动故障是旋转机械中相当常见的故障之一^[2]。根据故障产生原因，常见的松动故障有轴承座松动和旋转部件松动。前者可由轴承座的螺栓松动引发，后者由于轴承与轴承座存在松动间隙引发。

在现有关于松动故障的研究工作中，部分学者在模型动力学响应方面开展工作。曹青松等针对列车轮对系统中的轴承座松动问题，提出多部件耦合动力学模型，研究了松动间隙对于轮对系统的振动响应^[3]。郑美茹等在支承松动以及转子碰磨的前提下，构建了拉杆转子模型，对不同转速、松动刚度下的系统动力学响应作了研究^[4]。上述研究对松动故障作了定性研究，闻邦椿等对松动间隙进行了量化分析，并发现振动位移与最大松动间隙的相对大小将会直接影响时域波形的削波特征。譬如当振动位移小于松动间隙时，时域波形出现下端削波现象。而当振动位移大于松动间隙时，时域波形将出现上下削波现象，该项研究为松动间隙的量化提供了理论基础。^[5]

与此同时，部分学者直接研究松动故障的诊断技术，并取得一定成果。Yang等在强噪声背景下，采用归一化自相关分析和集成经验模态分解方法，研究了轴承座螺栓松动故障的微弱特征提取^[6]。Gong等提出一种基于次谐波共振和自适应随机共振方法，实现了松动识别^[7]。Wang等开发了一种新型的振动声学调制方法来检测多螺栓连接的松动程度，实现多螺栓连接的松散度检测^[8]。Stephan等构建了基于三轴和解调频域和时域振动数据的专家系统，用于轴承座松动等问题的诊断^[9]。Kuo等将反向传播神经网络应用于船舶推进系统的故障诊断，结合模糊算法获得最优传播神经网络和最优学习系数，针对轴承松动问题实现了91.7%的诊断正确率^[10]。蔡志新等针对行星齿轮轴承，提出一种模态分解方法，实现了96.43%的诊断正确率^[11]。Jafarian等在研究电机轴承松动故障时，提出一种三自由度感应电机综合建模和分析方法，并基于中性电压频谱分析技术提出一种轴承松动特征识别方法^[12]。Jung等在研究松动故障振动特征时发现机械松动故障常呈现整数次谐波分量，其中以转频0.5倍频最为典型^[13, 14]。但是，上述研究工作多针对于平稳工况，变转速工况下松动故障诊断问题研究较少。

事实上, 旋转机械常常工作在变转速工况下, 转速的时变特性为信号分析带来了更多的不确定性, 传统的信号分析方法在处理变转速工况信号时面对着更大的挑战^[15, 16]。尽管有阶次分析^[17]、经验模态分解^[18]、变分模态分解^[19]、小波分解等非平稳信号分析方法, 但上述方法均存在各自的技术缺点。譬如阶次分析存在插值误差, 以及无法实现模态分解的缺点^[20]。对于经验模态分解、变分模态分解、小波分解等, 又分别存在着模态混叠、分解层数优化、小波基优化等问题^[21-23]。可见, 现有的信号分析方法, 在面对非平稳工况下的复杂信号时仍面临一定挑战。

为实现非平稳信号的有效分解, 避免模态混叠等问题, 本文作者曾提出一种新的非平稳信号分析方法时频模态分解^[24]。在强噪声背景下, 该方法成功实现了非平稳多模态信号的模态分解。在该研究工作中, 并未研究该方法在不同工况下的模态分解性能, 方法的输出稳定性与自适应性有待验证。

为提高时频模态分解的自适应能力, 使之适应不同工况下的噪声强度, 本文提出一种自适应模态分解技术。为此, 本文将在不同噪声强度下分析时频窗宽等参数对于时频模态分解方法的信号分解性能, 并构建指标进行参数的优化选取。为验证该方法的有效性, 还将使用变转速下旋转机械松动故障信号进行检验。

本文结构安排如下。首先, 介绍一种新的非平稳信号处理方法自适应时频模态分解, 对该方法作理论推导, 并对时频窗宽等参数进行优化。然后, 采用变工况旋转机械松动故障实验信号对本文所提方法进行验证。最后, 对本文所提方法进行讨论, 并作总结。

1 理论框架

1.1 时频模态分解

1.1.1 理论推导

时频模态分解是一个旨在实现强噪声下多谐波非平稳信号模态分解的信号处理方法。该方法的详细步骤如下:

首先, 对于任意非平稳信号 $s(t)$, 采用窗函数 $h(\tau-t)$ 进行时域截取, 窗函数的中心时刻为 t , 时间变量为 τ 。上述时域截断操作可以获得中心时刻为 t 的非平稳信号片段 $s(t)h(\tau-t)$ 。当中心时刻 t 选取不同数值, 可获得对应的信号片段。当中心时刻 t 变化时, 对信号片段 $s(t)h(\tau-t)$ 进行傅里叶变换, 即可获得此时的频谱。各时刻频谱按照时刻 t 依次排列, 即为信号 $s(t)$ 的短时傅里叶变换时频分布(time-frequency distribution, TFD)。短时傅里叶变换可表示为

$$\begin{aligned} TFD(t, f) &= \langle s(t)h(\tau-t), \exp(-j2\pi f\tau) \rangle \\ &= \int_{-\infty}^{+\infty} s(\tau)h(\tau-t) \exp(-j2\pi f\tau) d\tau \end{aligned} \quad (1)$$

这里, $\langle \square, \square \rangle$ 表示内积, 此处 $\exp(-j2\pi f\tau)$ 表示复数空间内的向量 $\cos(2\pi f\tau) - j\sin(2\pi f\tau)$ 。

其次, 在旋转机械振动信号内部, 包含瞬时转速 $f_r(t)$ 与故障特征 $f_c(t)$ 。不同故障特征 $f_c(t)$ 与瞬时转速 $f_r(t)$ 具有相对应的固定倍率, 即故障特征阶次 (fault characteristic order, FCO)^[25]。故障阶次 FCO 的计算公式为

$$FCO = \frac{f_c(t)}{f_r(t)} = \text{常数} \quad (2)$$

根据 m 阶特征频率 $f_c^m(t) = m f_r(t)$, 在时频分布 $TFD(t, f)$ 中定义时频窗, 时频窗 $TFW_m(t, f)$ 的计算公式为

$$TFW_m(t, f) = \begin{cases} 1 & \text{if } |f(t) - f_c^m(t)| \leq w \\ 0 & \text{其它} \end{cases} \quad (3)$$

然后, 对于时频分布 $TFD(t, f)$, 采用时频窗 $TFW_m(t, f)$ 对作滤波处理, 可获得阶次 m 的时频分布 $TFD_m(t, f)$

$$TFD_m(t, f) = TFD(t, f) \times W_m(t, f) \quad (4)$$

最后，对阶次 m 的时频分布 $TFD_m(t, f)$ 分别作短时傅里叶逆变换，获得阶次 m 的时域信号 $x_m(t)$ 为，即

$$\begin{aligned} x_m(t) &= \langle TFD_m(t, f), \exp(j2\pi ft) \rangle \\ &= \int_{-\infty}^{+\infty} TFD_m(t, f) \exp(j2\pi ft) df \end{aligned} \quad (5)$$

通过时频模态分解，可将多谐波非平稳信号中的各阶模态进行一一分解，并生成对应的时域波形。该方法为信号中各阶模态的深度分析提供了可能。

图 1 绘制了时频模态分解的流程图，主要包括时频转换、时频窗构建、时频分解、信号重建等步骤。图中的窗宽参数需要人为设定，在多数情况下是能够实现信号的模态分解的。但是，为了进一步提高信号分解精度，还需要对窗宽参数作优化选取。

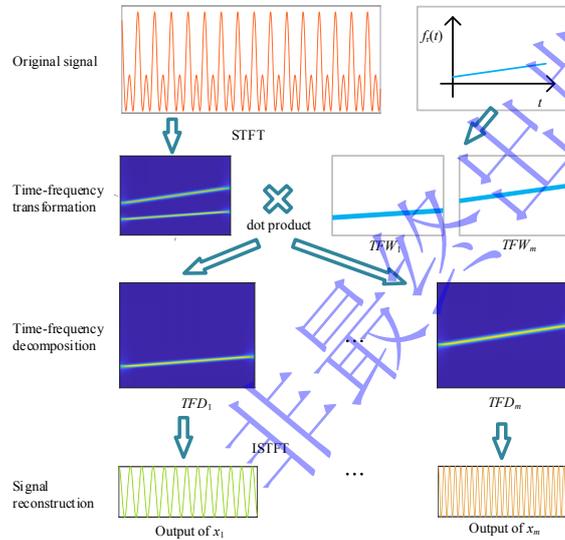


图 1 时频模态分解

Fig.1 Time-frequency modal decomposition

1.2 参数优化

在此前的研究中，并未对窗宽数值进行单独优化^[24]，所提的时频模态分解方法的噪声自适应能力需要进一步研究。

为此，本节将在不同噪声强度下，采用时频模态分解进行信号处理。通过输出信噪比、互相关系数等指标构建融合指标，对模态分解进行量化分析，获得窗宽 w 与指标的映射曲线。对窗宽 w 进行优化选取，获得兼顾不同工况背景的最优窗宽，从而实现自适应时频模态分解。

首先，以含噪多模态调频信号 $s(t)$ 为研究对象， $s(t)$ 定义为

$$\begin{aligned} s(t) &= N(t) + u_1 + u_{0.5} + u_{1.5} \\ &= N(t) + \sum_{i=1}^3 A_i \cos\left(\int_0^t 2\pi f_i(t) dt + \varphi_i\right) \end{aligned} \quad (6)$$

其中，幅值 A_1, A_2, A_3 分别取 1, 0.5, 0.5，初相位 $\varphi_1, \varphi_2, \varphi_3$ 为 0。 $N(t)$ 为高斯白噪声，通过 awgn 函数进行添加，信噪比 (signal-to-noise ratio, SNR) 取值为 $[-20\text{dB}, 0\text{dB}]$ 。 $s(t)$ 的信号长度为 L ，包含阶次为 $1\times$ 的转频成分 u_1 、阶次为 $0.5\times$ 的松动故障特征成分 $u_{0.5}$ 、阶次 $1.5\times$ 的松动故障伴随成分 $u_{1.5}$ 。信号中三个模态 $u_1, u_{0.5}, u_{1.5}$ 的瞬时频率分别为 $f_1(t), f_{0.5}(t), f_{1.5}(t)$ ，并定义在 (7) 式中

$$\begin{aligned}
f_1(t) &= f_r(t) = 10t + 40 \\
f_{0.5}(t) &= 0.5 \times f_r(t) \\
f_{1.5}(t) &= 1.5 \times f_r(t)
\end{aligned} \tag{7}$$

然后，利用时频模态分解技术，在窗宽 w 取值为 $[1,20]$ 的范围内，对信号 $s(t)$ 中阶次为 $0.5\times$ 和 $1.5\times$ 的模态进行分解，获得各阶模态时域波形 $x_m(t)$ 。

接着，构建融合指标对各阶模态时域波形 $x_m(t)$ 进行量化分析，并选取最优窗宽。融合指标基于信噪比 SNR 、输入输出互相关系数 C 。阶次 m 的 SNR 定义为

$$SNR_m = 10 \log_{10} \frac{\sum_{i=1}^L u_m^2(i)}{\sum_{i=1}^L (x_m(i) - u_m(i))^2} \tag{8}$$

阶次 m 的输入输出互相关系数 C_m 定义为

$$C_m = \frac{\sum_{i=1}^L (u_m(i) - \bar{u}_m)(x_m(i) - \bar{x}_m)}{\sqrt{\sum_{i=1}^L (u_m(i) - \bar{u}_m)^2 (x_m(i) - \bar{x}_m)^2}} \tag{9}$$

这里， u_m 表示阶次 m 的原始纯净信号， x_m 表示模态分解输出中阶次为 m 的信号波形。

SNR_m 和 C_m 两个指标分别表征信号的不同特征层面。构造融合指标 $CSNR_m$ 来同时表征输出信号的这两个特征层面。指标 $CSNR_m$ 被定义为

$$CSNR_m = \text{Norm}(C_m) \times \text{Norm}(SNR_m) \tag{10}$$

这里， SNR_m 与 C_m 的数据范围不同， SNR_m 的范围多为 10dB 以上，而 C_m 的范围为 $[0, 1]$ 。因此需要将指标进行归一化。(10) 式中的 Norm 表示归一化，这里采用的归一化类型为线性函数归一化，对原始指标数据进行线性变换，使结果映射到 $[0, 1]$ 的范围内。实现对原始数据的等比缩放，从而消除不同指标数值区间差异带来的影响。 SNR 归一化计算公式为

$$\text{Norm}(SNR_m) = \frac{SNR - \min(SNR_m)}{\max(SNR_m) - \min(SNR_m)} \tag{11}$$

C 归一化计算公式为

$$\text{Norm}(C_m) = \frac{C - \min(C_m)}{\max(C_m) - \min(C_m)} \tag{12}$$

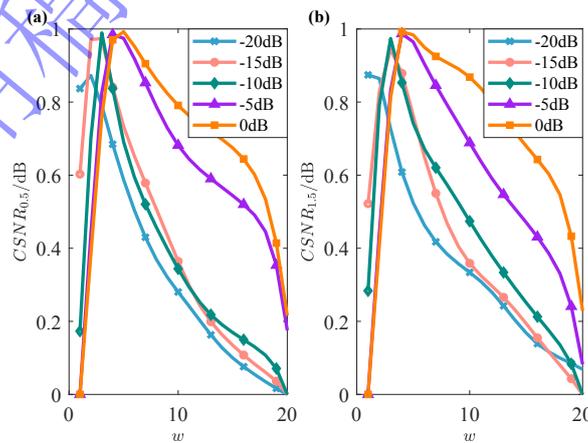


图 2 输入信噪比取不同数值时，窗宽 w 与不同阶次信号 $CSNR$ 的关系。(a) 输入信噪比取不同数值时， w 与 $CSNR_{0.5}$ 的关系；(b) 输入信噪比取不同数值时， w 与 $CSNR_{1.5}$ 的关系。

Fig.2 The curve of w versus $CSNR$ when input SNR takes different values. (a) The curve of w versus $CSNR_{0.5}$ when input SNR takes different values; (b) the curve of w versus $CSNR_{1.5}$ when input SNR takes different values.

针对不同阶次，在输入信噪比取不同数值时，图 2 绘制了窗宽 w 与 $CSNR$ 的关系。根据图 (a) 显示的 $0.5\times$ 阶次的 $CSNR_{0.5}$ 和图 (b) 呈现的 $1.5\times$ 阶次的 $CSNR_{1.5}$ 曲线，可以观察到在不同初始噪声强度下，随着窗宽数值的增加， $CSNR$ 数值均表现出非线性趋势，即呈现出“先升后降”的趋势。值得注意的是，随着初始信噪比的降低， $CSNR$ 取得最大值时所对应的最优窗宽数值逐渐降低。整体上，最优窗宽 w 聚集在 4 左右。因此，我们可以合理地确定窗宽参数为 $w=4$ 作为最佳选择，从而实现自适应时频模态分解。

2 方法验证

工程中的松动故障分为三类，分别为图 3 (a) 中的支座刚度低、底座破坏导致的结构松动，图 3 (b) 中的轴承座螺栓松动，图 3 (c) 中的轴径、轴承内环等旋转件接触松动^[13, 26]。其阶次特征分别对应于图 3 (d)、图 3 (e)、图 3 (f)。阶次谱中可见，图 3 (a) 类松动故障的阶次谱仅包含 $1\times$ 转频特征，图 3 (b) 和图 3 (c) 类故障都会引发 $0.5\times$ 阶次特征。

为检验所提方法在松动故障诊断方面的性能，在实验室中搭建了轴承座螺栓松动故障诊断实验台，对应于图 3 (b) 类故障。同时，对某工程设备传动系统的旋转件松动故障进行了数据采集与验证，对应于图 3 (c) 类故障。

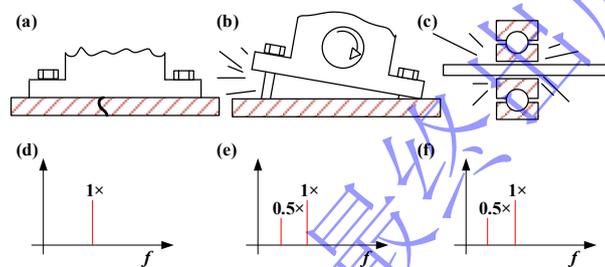


图 3 松动故障及阶次谱

Fig.3 Looseness fault and order spectrum

2.1 轴承座松动

为验证所提方法对于旋转机械松动故障的诊断效果，在实验室中搭建了变转速滚动轴承故障诊断实验台，进行支承松动故障诊断验证。

图 4 给出了采集信号的实验装置，实验台由额定功率 5kW 的电机型号 198BGL-H5P515/120 驱动。径向加载通过 CX-SD100*50 型液压缸进行的，施加的径向力 3.9kN。实验中所使用的轴承型号是 MFR78118，左右支承轴承型号为 SKF-NU208ECP。采用 NI-9234 型号的信号采集卡，采样频率设置为 10240Hz。选用 DH-1A202 型号的加速度传感器测量振动信号，采用磁铁吸附的方式安装在故障轴承的轴承座上方。

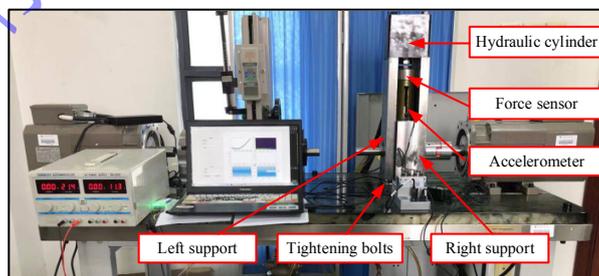


图 4 轴承座松动故障实验台.

Fig.4 Bearing seat looseness fault test bench

(i) 工况 1

为模拟轴承座松动故障，在轴承座安全前，预先在轴承座的其中一个安装螺栓处、轴承座与台面之间垫入厚度为 4mm 的垫块。然后对各处部件进行连接与紧固之后，取出 4mm 垫块。设定电机

转速按照特定曲线进行变化，变转速工况包括转速为 30 的定速运行阶段，以及转速变化率为 5 $\text{Hz}\cdot\text{s}^{-1}$ 的加速运行阶段。上述阶段时长分别为 0.5 秒和 1 秒。瞬时转速 $f_r(t)$ 满足以下公式

$$f_r(t) = \begin{cases} 30, & 0 \leq t < 0.5 \\ 5t + 27.5, & 0.5 \leq t \leq 1.5 \end{cases} \quad (13)$$

选取变转速下的轴承座松动故障振动信号 $s(t)$ ，作为时频模态分解的输入信号。同时，基于电机设定的转速信号 $f_r(t)$ ，在 $[0.2, 1.9]$ 阶次区间内构建时频窗组 $TFW_m(t, f)$ ，并进行时频模态分解。

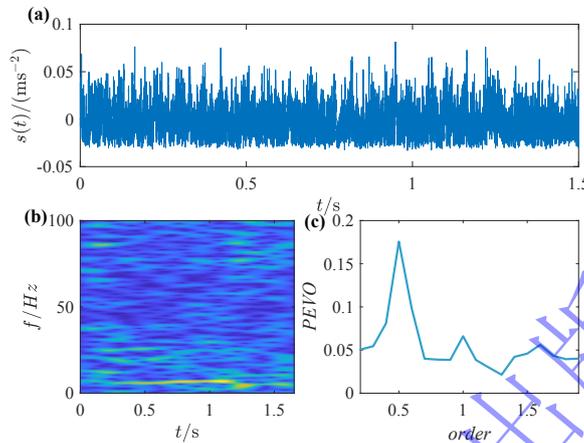


图 5 工况 1 的轴承座松动故障诊断. (a) 轴承座松动故障信号的时域波形图; (b) 轴承座松动故障的时频图; (c) 轴承座松动故障的自适应时频模态分解输出.

Fig.5 Fault diagnosis of bearing support looseness fault under operating condition 1. (a) Time-domain waveform of bearing seat looseness fault signal; (b) time frequency distribution of bearing seat looseness fault signal; (c) adaptive time-frequency modal decomposition output of bearing seat looseness fault signal.

图 5 绘制了变转速下滚动轴承座松动故障的诊断结果。图 5 (a) 中绘制了振动信号 $s(t)$ 的时域波形，单位 $\text{m}\cdot\text{s}^{-2}$ 。图中可见明显的非对称冲击特征，在波形下方存在明显的削波现象，而在波形上方则为连续的时域冲击波形，这是轴承座松动的典型特征。同时，根据其“下削波”特征，判断此时振动位移小于松动间隙^[5]。图 5 (b) 为信号 $s(t)$ 的时频图，时频图中仅仅在低频区存在能量聚集，无明显的代表松动故障的 0.5 倍频时频脊线，因此无法判断有无松动故障。图 5 (c) 为自适应时频模态分解输出，选取最优窗宽 $w=4$ 。图 5 中可见，在转频的 0.5 倍频处有较高能量，并达到转频能量的 2 倍以上，说明此时已经存在较为明显的轴承座松动故障。

(ii) 工况 2

改变试验台工况，将螺栓松动间隙调整为 6mm，设定电机的瞬时转速 $f_r(t)$ 为式(14)

$$f_r(t) = \begin{cases} 25, & 0 \leq t < 0.5 \\ 5(t - 0.5) + 25, & 0.5 \leq t < 1.5 \\ 30, & 0.5 \leq t \leq 1.8 \end{cases} \quad (14)$$

采用文中所提方法，对工况 2 的信号进行处理。图 6 绘制了工况 2 信号处理结果。图中可见，由于故障程度从 4mm 增长到 6mm，图 6(a)中时域波形的幅值也从图 4(a)的幅值 0.08 增长到 0.12。图 6(b)时频图中包含强噪声，无法直接进行故障诊断。图 6(c)的阶次谱中可见 $0.5 \times$ 阶次能量进一步提高，由原文中的 0.18 提升到 0.22，转频成分和 $1.5 \times$ 阶次成分的 PEVO 指标降低。

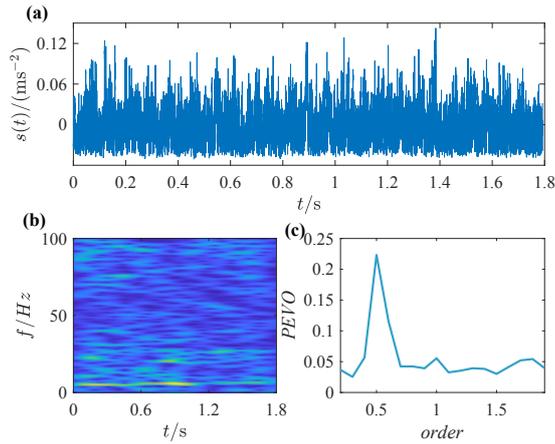


图 6 工况 2 的轴承座松动故障诊断. (a) 轴承座松动故障信号的时域波形图; (b) 轴承座松动故障的时频图; (c) 轴承座松动故障的自适应时频模态分解输出.

Fig.6 Fault diagnosis of bearing support looseness fault under operating condition 2: (a) Time-domain waveform of bearing seat looseness fault signal; (b) time frequency distribution of bearing seat looseness fault signal; (c) adaptive time-frequency modal decomposition output of bearing seat looseness fault signal.

2.2 旋转部件松动

图 7 所示, 某工程装备传动系统由直列 6 缸发动机驱动, 最大扭矩 1180Nm, 动力通过弹性联轴器与传动轴传递到变速箱负载。信号采集系统为 DH-5925N, 传感器为 DH-1A315 压电式加速度传感器, 采样频率为 10240Hz, 安装在联轴器侧边的发动机壳体上方。在联轴器内部安装有一套滑动轴承, 因制造装配等原因, 滑动轴承与外圈存在间隙, 从而导致旋转部件松动故障。

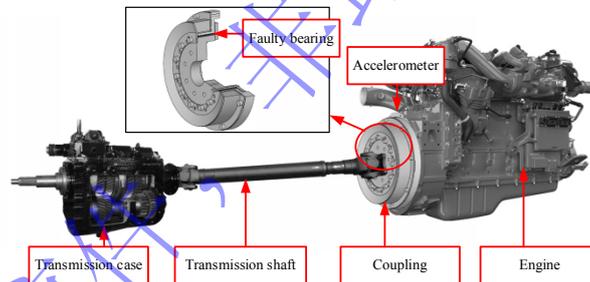


图 7 某工程装备传动系统.

Fig.7 Transmission system of a certain engineering equipment

(i) 工况 1

发动机瞬时转速 $f_r(t)$ 满足以下公式

$$f_r(t) = 10t + 30, \quad 0 \leq t \leq 1.2 \quad (15)$$

图 8 绘制了变转速下某工程装备传动系统旋转部件松动故障的诊断结果。图 8 (a) 绘制了变转速轴承振动信号 $s(t)$ 的时域波形, 单位 $m \cdot s^{-2}$, 图中可见存在时域冲击特征, 但无法直接判断出有无松动故障。图 8 (b) 为信号 $s(t)$ 的时频图, 图中转频以及 0.5 倍频的时频脊线模糊, 能量聚集度较低。尽管 1.5 倍频时频脊线较为清晰, 但无法据此直接判别松动故障的有无。图 8 (c) 为自适应时频模态分解输出, 选取最优窗宽 $w=4$ 。图中可见, 存在转频和 0.5 倍频, 且两者能量相当, 说明此时已经存在较为明显的松动故障。同时, 阶次谱中伴随 1.5 倍频成分, 进一步验证松动故障的存在。

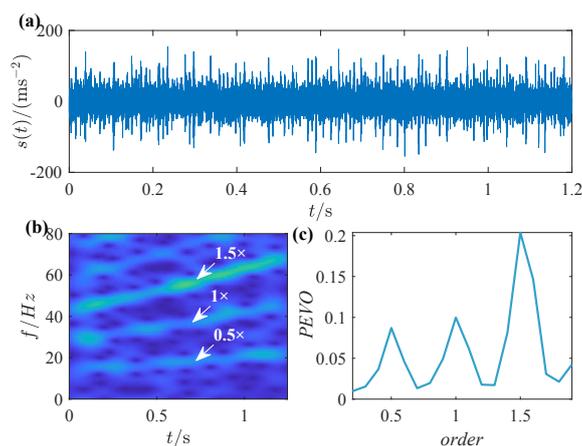


图 8 工况 1 某工程装备旋转部件松动故障诊断. (a) 旋转部件松动故障信号的时域波形图; (b) 旋转部件松动故障信号的信号时频图; (c) 旋转部件松动故障的自适应时频模态分解

Fig.8 Rotating parts looseness fault diagnosis in a certain engineering equipment under operating condition 1: (a) Time-domain waveform of rotating parts looseness fault signal; (b) Time frequency distribution of rotating parts looseness fault signal; (c) Adaptive time-frequency modal decomposition output of rotating parts looseness fault signal

(ii) 工况 2

在发动机减速状态下，采集工况 2 的数据。发动机瞬时转速 $f_r(t)$ 满足以下公式

$$f_r(t) = -4t + 25, \quad 0 \leq t \leq 1.2 \quad (16)$$

图 9 绘制了减速状态下某工程装备传动系统旋转部件松动故障的诊断结果。图 9 (a) 中的振动信号 $s(t)$ 的时域波形存在时域冲击特征，但无法直接判断出有无松动故障，结合时频图中的能量较高的 $3\times$ 成分，推测为 6 缸发动机活塞运动引起的冲击。图 9 (b) 为信号 $s(t)$ 的时频图，图中转频以及 0.5 倍频的时频脊线模糊，能量聚集度较低。图 9 (c) 为自适应时频模态分解输出，窗宽 w 选取为 4。图中可见，存在较高幅值的 $0.5\times$ 阶次，说明此时已经存在较为明显的松动故障。

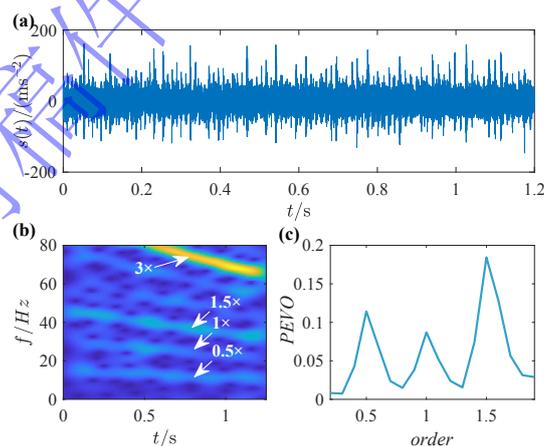


图 9 工况 2 某工程装备旋转部件松动故障诊断. (a) 旋转部件松动故障信号的时域波形图; (b) 旋转部件松动故障信号的信号时频图; (c) 旋转部件松动故障的自适应时频模态分解

Fig.9 Rotating parts looseness fault diagnosis in a certain engineering equipment under operating condition 2. (a) Time-domain waveform of rotating parts looseness fault signal; (b) time frequency distribution of rotating parts looseness fault signal; (c) adaptive time-frequency modal decomposition output of rotating parts looseness fault signal

2.3 算法特性分析

(i) 对比验证

当前，主流信号分解方法包括经验模态分解、小波分解、变分模态分解等。其中经验模态分解、小波分解的研究历史较久，近年来变分模态分解获得了研究人员的关注，该方法在一定程度上解决了经验模态分解的模态混叠问题。因此，选用变分模态分解作为对照方法，对比验证所提方法与主流模态分解方法的差异性。

为降低变分模态分解在进行多模态数据分解中的难度，采用低通滤波对实验信号进行滤波处理。图 8 可见，故障特征频带位于 80Hz 以下，因此采用截止频率为 150Hz 的低通滤波器，对旋转部件松动加速工况(i)中的信号进行滤波处理。采用变分模态分解，对滤波后的信号进行 5 层分解。图 10 中可见，在分解后的 imf5 中，出现低于 100Hz 的频带，但谱线较为复杂，仍然无法直接判断其表征的故障。

由此可见，在处理此类噪声较强、转速时变、成分复杂的信号时，现有的模态分解容易受到噪声干扰，并出现模态混叠的问题。分解获得的本征模态函数频带较宽，无法实现准确的模态分解，同时也无法实现非平稳特征提取与故障诊断。

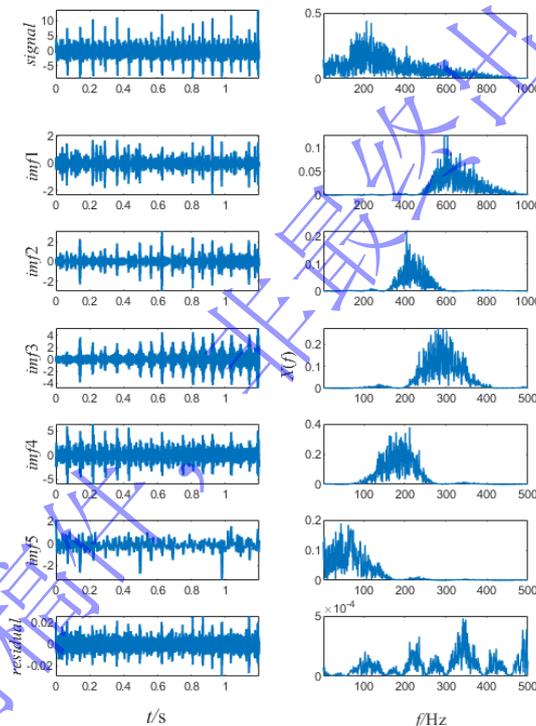


图 10 基于变分模态分解的某工程装备旋转部件的工况 1 松动故障诊断

Fig.10 Rotating parts looseness fault diagnosis in a certain engineering equipment by variational mode decomposition under operating condition 1

(ii) 稳定性验证

为验证所提方法的检测稳定性，在工况 1 下进行了 10 次轴承座松动故障测试，采用所提方法进行模态分解，并分别统计 $0.5\times$ 、 $1\times$ 、 $1.5\times$ 阶次的 PEVO 指标。

表 1 展示了基于 TFMD 的轴承座松动故障 PEVO 指标统计结果。对比发现， $0.5\times$ 阶次的多次试验数据均处于 0.1 左右， $1\times$ 阶次的多次试验数据均处于 0.09 左右， $1.5\times$ 阶次的多次试验数据均处于 0.18 左右，未出现明显偏离整体分布的离群点。这说明所提方法能够在多次实验中保证诊断稳定性，对于噪声、转速波动等随机干扰具有较高的抗干扰能力。

表 1 基于 TFMD 的松动故障 PEVO 指标统计结果

Table 1 Statistical result of PEVO in looseness faults by TFMD

测试序号	0.5×	1×	1.5×
1	0.092499	0.0933931	0.183413
2	0.103231	0.0976907	0.186211
3	0.093840	0.1139052	0.167082
4	0.116481	0.0933782	0.174618
5	0.105514	0.0814482	0.189346
6	0.113997	0.0907716	0.198186
7	0.130626	0.0760067	0.189975
8	0.115979	0.1014092	0.171659
9	0.124945	0.0942314	0.168231
10	0.109956	0.1067112	0.194692

图 11 绘制了 10 次统计数据分布结果。图 11 (a) 中可见, 0.5×和 1×的 PEVO 结果接近, 均处于 0.1 附近, 其中 0.5×略大于 1×的 PEVO, 1.5×的 PEVO 位于 0.18 附近, 未出现离群点。图 11 (b) 中对上述三个阶次的 PEVO 数值进行了分布统计, 可见 0.5×、1×、1.5×这三个阶次的 PEVO 结果都相对稳定且集中。

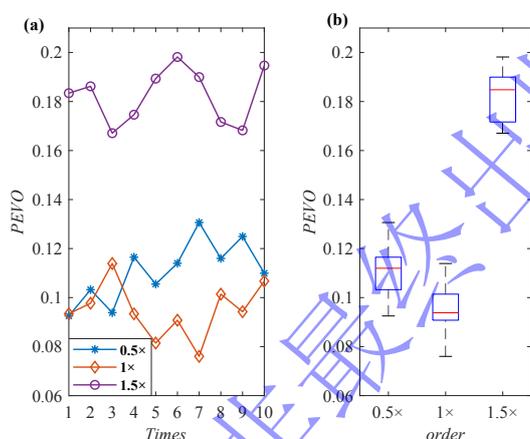


图 11 基于 TFMD 的某工程装备旋转部件的工况 1 松动故障诊断统计. (a) 10 次试验数据的 PEVO 数据折线图; (b) 10 次试验数据的 PEVO 数据分布.

Fig.11 Statistical result of PEVO by TFMD in certain engineering equipment looseness faults diagnosis under operating condition 1. (a) Line graph of PEVO data from 10 experiments; (b) box plot of PEVO data from 10 experiments.

3 结论

本文针对旋转机械松动故障作了研究, 并提出了一种用于变转速、强噪声背景下的松动故障诊断的自适应时频模态分解方法。该方法在使用过程中, 需要基于设备瞬时转速信息, 这在一定程度上可能限制了该方法的适用性。但在工程实际中, 转速测量的技术难度较低, 且现有大型设备多已配备转速测量装置, 为该方法的应用提供了硬件基础。

在文中, 为了提升该方法的多工况适应能力, 采用信噪比、互相关系数等构建了融合指标, 对窗宽取值问题进行了优化。在实验验证方面, 采用多种故障类型的信号对所提方法做了检验, 结果表明:

- (1) 自适应时频模态分解可兼顾不同强度的噪声背景, 适用于多工况下的非平稳信号处理。
- (2) 对于变转速工况下的松动故障, 自适应时频模态分解能有效实现故障特征提取, 对于噪声具有免疫力。
- (3) 自适应时频模态分解可用于不同类型的松动故障诊断, 具有一定的自适应与泛化能力。

参考文献

- [1] Liang H, Cao J, Zhao X. Multi-scale dynamic adaptive residual network for fault diagnosis[J]. *Measurement*, 2022, 188: 110397.
- [2] Wang P F, Xu H Y, Ma H, et al. A Study on the dynamic characteristics of a planetary gear train rotor system with misalignment of bearings. *J Vib Eng*, 2023, 36(01): 116-27
(王鹏飞, 徐宏阳, 马辉, 等. 含轴承倾斜不对中的行星轮系-转子系统动态特性研究[J]. 振动工程学报, 2023, 36(01): 116-27.)
- [3] Cao Q S, Guo X B, Xiong G L, et al. Research on dynamic characteristics of loose support system for rolling bearings in high speed trains[J]. *Journal of Mechanical Engineering*, 2016, 52(21): 87-95
曹青松, 郭小兵, 熊国良, 等. 高速列车滚动轴承支承松动系统动力学特性研究[J]. 机械工程学报, 2016, 52(21): 87-95.
- [4] Guo M R, Hei D. Dynamic analysis of a rod rotor bearing system with loose base and rubbing faults[J]. *Journal of Mechanical & Electrical Engineering*, 2020, 37(12): 1439-46
(郑美茹, 黑棣. 具有基座松动和碰摩故障的拉杆转子-轴承系统动力学分析[J]. 机电工程, 2020, 37(12): 1439-46.)
- [5] Z J, Wen B C. Frequency characteristics analysis of a rotor system with loose supports at both ends[J]. *China Mechanical Engineering*, 2008, (01): 68-71
(张靖, 闻邦椿. 两端支座松动转子系统的频率特性分析[J]. 中国机械工程, 2008, (01): 68-71.)
- [6] Yang C, Yang J, Zhang S, et al. Extracting weak multi-frequency signal in heavy colored noise[J]. *J Braz Soc Mech Sci Eng*, 2020, 42(11): 1-12.
- [7] Gong T, Yang J, Sanjuán M A F, et al. Adaptive stochastic resonance for bolt looseness identification under strong noise background[J]. *J Comput Nonlin Dyn*, 2022, 17(7): 071003.
- [8] Wang F, Song G. Monitoring of multi-bolt connection looseness using a novel vibro-acoustic method[J]. *Nonlinear Dynam*, 2020, 100(1): 243-254.
- [9] Ebersbach S, Peng Z. Expert system development for vibration analysis in machine condition monitoring[J]. *Expert Syst Appl*, 2008, 34(1): 291-299.
- [10] Kuo H-C, Wu L-J, Chen J-H. Neural-fuzzy fault diagnosis in a marine propulsion shaft system[J]. *J Mater Process Tech*, 2002, 122(1): 12-22.
- [11] Cai Z X, Dang Z, LV Y. Application of Adaptive Dynamic Mode Decomposition and GA-SVM in Fault Classification of Planetary Bearings[J]. *Chinese Journal of Engineering*, 2023, 45(9): 1559-1568
(蔡志鑫, 党章, 吕勇. 自适应动态模式分解和 GA-SVM 在行星轴承故障分类中的应用[J]. 工程科学学报, 2023, 45(9): 1559-1568.)
- [12] Jafarian M J, Nazarzadeh J. A TDF Model in induction machines for loose bearing diagnosis by neutral voltage[J]. *IEEE T Ind Electron*, 2020, 67(10): 8155-8163.
- [13] Jung J, Lee S B, Lim C, et al. Electrical monitoring of mechanical looseness for induction motors with sleeve bearings[J]. *IEEE T Energy Conver*, 2016, 31(4): 1377-1386.
- [14] An X, Jiang D, Li S, et al. Application of the ensemble empirical mode decomposition and Hilbert transform to pedestal looseness study of direct-drive wind turbine[J]. *Energy*, 2011, 36(9): 5508-5520.
- [15] Choudhury M D, Blincoe K, Dhupia J S. An overview of fault diagnosis of industrial machines operating under variable speeds[J]. *Acoust Aust*, 2021, 49(2): 229-238.
- [16] Ma Y, Lv Y, Yuan R, et al. Matching synchroextracting transform for mechanical fault diagnosis under variable-speed conditions[J]. *IEEE T Instrum Meas*, 2022, 71: 1-12.
- [17] Lu S, Yan R, Liu Y, et al. Tachless speed estimation in order tracking: a review with application to rotating machine fault diagnosis[J]. *IEEE T Instrum Meas*, 2019, 68(7): 2315-2332.

- [18] Yang J H, Han S, Zhang S. Empirical mode decomposition of weak fault characteristic signals of rolling bearings under strong noise background[J]. *J Vib Eng*, 2020, 33(03): 582-589
(杨建华, 韩帅, 张帅, 等. 强噪声背景下滚动轴承微弱故障特征信号的经验模态分解[J]. 振动工程学报, 2020, 33(03): 582-9.)
- [19] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE T Signal Proces*, 2013, 62(3): 531-544.
- [20] Xu Y, Zhang K, Ma C, et al. Optimized LMD method and its applications in rolling bearing fault diagnosis[J]. *Meas Sci Technol*, 2019, 30(12): 125017.
- [21] Gong T, Yuan X, Yuan Y, et al. Application of tentative variational mode decomposition in fault feature detection of rolling element bearing[J]. *Measurement*, 2019, 135: 481-492.
- [22] Zhang J, Hou G, Ma B, et al. Operating characteristic information extraction of flood discharge structure based on complete ensemble empirical mode decomposition with adaptive noise and permutation entropy[J]. *J Vib Control*, 2018, 24(22): 5291-5301.
- [23] Brechet L, Lucas M-F, Doncarli C, et al. Compression of biomedical signals with mother wavelet optimization and best-basis wavelet packet selection[J]. *IEEE T Biomed Eng*, 2007, 54(12): 2186-2192.
- [24] Shan Z, Wang Z, Yang J, et al. Novel time frequency mode decomposition and information fusion for bearing fault diagnosis under varying-speed condition[J]. *IEEE T Instrum Meas*, 2023, 72: 1-10.
- [25] Wang T, Liang M, Li J, et al. Rolling element bearing fault diagnosis via fault characteristic order (FCO) analysis[J]. *Mech Syst Signal Pr*, 2014, 45(1): 139-153.
- [26] Shi X, Wang G, Si J. *Mechanical Fault Diagnosis and Typical Case Analysis*. Beijing: Chemical Industry Press, 2013
(时献江, 王桂荣, 司俊山. 机械故障诊断及典型案例解析. 北京: 化学工业出版社, 2013)